

Stručni rad

UDK: 519.246.8(049.3)

Datum primitka članka u uredništvo: 19. 7. 2018.

Datum slanja članka na recenziju: 10. 10. 2018.

Datum prihvatanja članka za objavu: 21. 11. 2018.

Dr. sc. Tihana Škrinjarić

PRIKAZ KNJIGE

Essentials of Time Series for Financial Applications

Autori: Massimo Guidolin i Manuela Pedio

Izdavač: Academic Press, Elsevier

Mjesto i godina izdanja: Ujedinjeno Kraljevstvo, 1st edition, 2018.

Broj stranica: 434

ISBN: 9780128134092

Ekonometrija financijskih vremenskih serija brzo je rastuće područje ekonometrije koje se ubrzano širi i u teoriji i primjenama. Stoga ne čudi postojeći obujam knjiga i materijala posvećenih ovome području; kao i što se ono kontinuirano povećava. U mnoštvu dostupnih udžbenika potrebno je naći one koji na razumljiv način predstavljaju teoriju čitateljima, prate suvremene trendove te po mogućnosti imaju primjere koje čitatelj sam može reproducirati kako bi lakše svladao svu materiju. Početnicima je nužno kvalitetno svladati materiju na samome početku. Knjiga „*Essentials of Time Series for Financial Applications*“ rezultat je višegodišnjeg predavačkog iskustva dvoje autora, stoga predstavlja kombinaciju potrebne teorije iz područja financijske ekonometrije i mnogobrojnih primjera kako bi se teorija približila čitateljima.

Uz samu knjigu (bilo elektroničku ili papirnatu verziju), *online* su dostupni dodatni materijali vezani uz određena poglavlja te podaci kako bi čitatelji sami mogli izvršiti izračune i procjene i još lakše pratiti interpretacije i rezultate u knjizi. Svi primjeri se odnose na financijske vremenske serije poput prinosa dionica, obveznica, kamatnih stopa itd. te se analiziraju brojni financijski modeli (CAPM¹, VaR², Fama-French, Carhartov model, ...). Pri tom se uvažava financijska i ekonomska smislenost i interpretacija uz formalno kvantitativno modeliranje. Dodatno, elektroničko izdanje knjige sadrži poveznice na sve reference koje autori koriste. Tako primjerice, ako čitatelja zanimaju detalji vezani uz pojedini model koji se obrađuje u knjizi, izravnim odabirom reference može na internetu otvoriti pojedini članak.

Prva četiri poglavlja mogla bi se svrstati u osnove ekonometrije koje je nužno znati prije bilo kakvog modeliranja vremenskih serija. Prvo poglavlje kao uvodno predstavlja za-

¹ Capital Asset Pricing Model.

² Value at Risk.

okruženu cjelinu o linearnoj regresiji, koja je temelj za bilo kakvu ekonometrijsku analizu pa tako i vremenskih serija. Uključene su dvije metode procjene parametara u regresiji, narušavanje pretpostavki linearne regresije, inferencija te su uz definicije i izvode u matričnoj formi prikazani primjeri i njihove interpretacije. Za dodatno zainteresirane se u dodatku prikazuje formalan dokaz nepristranosti OLS³ procjenitelja. U manje od 40 stranica ovo prvo poglavlje sažima nužne osnove koje je potrebno svladati za daljnju ekonometrijsku analizu. Ovo poglavlje je potreban preduvjet za preostala, ali zato je sažeto, koncizno i izravno. Drugo poglavlje analizira ARMA⁴ modele kao osnovne modele za prognoziranje financijskih vremenskih serija. Osnovna obilježja ARMA vremenskih serija prikazana su i analitički i grafički, kao i što se jasno izvode njihova osnovna svojstva. Cjelokupan Box-Jenkins pristup modeliranja ovakvih serija je prikazan uz detaljan primjer, a na kraju poglavlja se posvećuje pozornost samome prognoziranju. S obzirom na značaj operatora pomaka (*lag operator*) ne samo kod univarijatnih modela, već i kod multivarijatnih, u dodatku na kraju poglavlja razmatraju se definicija i svojstva tog operatora, kao i dokaz nekih svojstava operatora pomaka. Ponovno se radi o sažetom poglavlju.

Treće poglavlje se nadovezuje na drugo, jer razmatra vektorske ARMA modele. S obzirom da u današnjim uvjetima na financijskim tržištima nije realno pretpostavljati da cijene, prinosi i rizici jedne financijske imovine ne ovise o drugima, razmatraju se vektorski modeli kako bi se istodobno modelirale interakcije prinosa i rizika. U poglavlju se razmatraju VAR⁵ modeli, kros-korelacijske matrice, kao i prognoziranje temeljem obrađivanih modela, pri čemu se detaljno interpretiraju analitički izrazi koji se razmatraju. Posebna pozornost se posvećuje razlikovanju strukturnog od reduciranog oblika modela i na jednostavan način se objašnjava potreba za Cholesky dekompozicijom matrice varijanci i kovarijanci slučajne komponente u modelu (s čime mlađi čitatelji ponekad imaju problema). Ono što je također korisno za čitatelja, autori kod konkretnog pojma navode daljnji izvor literature za strože matematičke zapise, kako bi zainteresirani čitatelj mogao detaljnije proučiti neki pojam ili model s formalnije strane. Dodatna vrijednost pronalazi se u uvodu u *bootstrap* metode, s obzirom da je moguće funkcije impulsnog odaziva (IRF, *impulse response function*) konstruirati pomoću njih, a spomenute metode imaju određene prednosti u odnosu na uobičajene procjene IRF funkcija. U četvrtome poglavlju se razmatraju nestacionarne vremenske serije, testiranje nestacionarnosti testovima jediničnih korijenja te kointegracija. Dodatna vrijednost u poglavlju u odnosu na neku drugu postojeću literaturu jest što autori prikazuju što se događa s vremenskom serijom i posljedično modelom ako se u njoj prepozna kriva vrsta nestacionarnosti. Osim DF i ADF⁶ testa, u poglavlju se razmatraju i neki alternativni testovi nestacionarnosti, kao i kvazi diferenciranje. Ovdje su obrađeni opsežni primjeri (kroz nekoliko strana) koji bi trebali ukloniti bilo kakve nejasnoće. Nakon definiranja kointegracije, predložuje se nekoliko alternativnih načina njenog testiranja: Engle i Granger pristup i VECM⁷ pristupi (Johansenov te Stock i Watsonov pristup testiranja).

³ Ordinary least squares.

⁴ AutoRegresive Moving Average.

⁵ Vector AutoRegression.

⁶ Dickey Fuller; Augmented Dickey Fuller.

⁷ Vector Error Correction Model.

Potom bi se u posebnu skupinu mogla grupirati poglavlja 5 – 7 jer se bave modeliranjem rizika. Peto poglavlje posvećeno je univarijatnim modelima volatilnosti kao jedna od prirodnih tema za analizu u financijama - rizik. Stoga ne čudi opseg poglavlja kao jednog od najvećih u samoj knjizi. Autori pristupaju analizi na način da nakon stiliziranih činjenica o riziku prvo prikazuju pomične prosjeke izračuna rizika, a potom najpopularnije GARCH modele i njihova obilježja (linearne i nelinearne modele: EGARCH, *threshold*, *power* GARCH, QARCH, NAGARCH, C-GARCH, GARCH-M⁸). Osim pretpostavke normalnosti inovacijskog procesa, dodatna vrijednost u poglavlju nalazi se u obrađivanju pretpostavke Studentove i GED (*generalized error distribution*) distribucije inovacijskog procesa, kao i dodatku egzogenih varijabli u GARCH specifikaciju modela. Naravno, osim formalnih testova i krivulje učinka vijesti (*news impact curve*), na kraju poglavlja se obrađuje prognoziiranje pomoću ovakvih modela. Dodatno se metoda najveće vjerodostojnosti (ML), metoda momenata (MM) i kvazi ML (*quasi MLE*), detaljno obrađuju, s obzirom na narav GARCH modela i potrebe za njihovom primjenom. Autori poseban osvrt rade i na frekvenciju podataka koja se koristi u analizi i kako ona utječe na rezultate procjena. Stoga na kraju poglavlja daju uvod u slabe GARCH procese (*weak GARCH*) i temporalnu agregaciju.

Šesto poglavlje prirodan je nastavak na drugo, jer se obrađuju multivarijatni modeli volatilnosti. Ovdje se odmah na početku čitatelja upozorava na složenost problema kada se razmatra više vremenskih serija s obzirom na broj parametara koje je potrebno procijeniti u matrici varijanci i kovarijanci za potrebe modeliranja portfelja. Ponovno se i u ovome poglavlju najprije prikazuju osnovni pomični prosjeci izračuna uvjetnih kovarijanci, nakon čega se razmatraju MGARCH modeli: VECH (*vector conditional heteroskedasticity*), BEKK (Baba-Engle-Kraft-Kroner), CCC (*constant conditional correlation*), DCC (*dynamic conditional correlation*), *copula*-GARCH (kopula), faktorski i ortogonalni GARCH. Svaki od razmatranih modela prikazan je kroz vrlo detaljan primjer i njegove interpretacije (neki primjeri su razmatrani čak na nekoliko strana). Za svaki model se navode prednosti i nedostaci te mogućnosti primjene kako se čitatelj ne bi pogubio u mnoštvu mogućnosti. Sedmo poglavlje bavi se stohastičkom volatilnosti (SV), koju autori razlikuju od (M)GARCH modela. Kako se u SV modelima volatilnost ne može mjeriti s obzirom na dostupne informacije (trenutno stanje volatilnosti nije poznato sa sigurnošću), procjenu trenutne volatilnosti potrebno je filtrirati. Stoga poglavlje započinje osnovama Kalmanovog filtra. Nakon toga se obrađuju dva osnovna SV modela: *normal mixture* i *log-normal two-factor* model te su ponovno razmatrani opsežni primjeri (na čak 7 stranica u ovome slučaju). S obzirom na određene nedostatke Kalmanovog filtra, nekoliko rečenica se dodatno posvećuje drugim pristupima modeliranju, zajedno s referencama za daljnje izučavanje. Potom se obrađuje druga generacija SV modela u kojima se omogućavaju skokovi (*jumps*) u stohastičkim diferencijalnim jednadžbama, kao i duga memorija. Na kraju poglavlja vrši se kratka usporedba GARCH i SV modela, s nekoliko recentnih referenci.

⁸ GARCH – Generalized Autoregressive Conditional Heteroskedasticity, EGARCH – Exponential GARCH, QARCH – quadratic ARCH, NAGARCH – nonlinear asymmetric GARCH, C-GARCH – component GARCH, GARCH-M – GARCH in mean.

Konačna skupina koja bi se mogla izdvojiti u zasebnu su posljednja tri poglavlja koja se posebno bave nelinearnostima u financijskim serijama i odabirom frekvencije podataka. U osmome poglavlju fokus se vrši na strukturne promjene u podacima, promjene režima i nelinearnosti. Autori naglašavaju da je potrebno razlikovati kada koristiti: modele s konstantnim parametrima; modele u kojima dolazi do strukturnih lomova te modele u kojima kontinuirano dolazi do promjena svojstava i međuodnosa varijabli (modele s promjenom režima). Stoga se najprije razmatra testiranje strukturnih lomova u podacima. Detaljnije se obrađuju popularni Chow i CUSUM (*cumulative sum*) test te Andrews i Quandtov test; kao i Bai i Perronov test za više lomova u procijenjenom modelu. Već obrađeni testovi jediničnih korijena (u četvrtome poglavlju) sada se proširuju u testove jediničnih korijena uz strukturne lomove u podacima/vremenskim serijama (bilo u razini i/ili trendu). Kako danas sve više vremenskih serija obilježavaju takvi lomovi, nekoliko stranica osmoga poglavlja posvećeno je takvim testovima, zajedno s primjerima. *Threshold* regresijski i autoregresijski modeli se razmatraju kao uvodni modeli promjene režima; gdje se razmatraju slučajevi ako je poznata referentna razina (*threshold*) određene varijable gdje dolazi do promjene u ponašanju, a potom se obrađuje procedura otkrivanja koja je to referentna razina (globalnom optimizacijom te sekvencijalnim testovima). *Smooth transition* i SETAR modeli (modeli s glatkim prijelazom te SETAR – *self extracting autoregression*) su prirodan nastavak na prethodno obrađene i nakon ova potonja dva, na kraju je poglavlja nekoliko strana posvećeno testiranju nelinearnosti u modelima.

Deveto poglavlje se nadovezuje u određenoj mjeri na osmo. Dok se u osmom prikazivalo modeliranje prelaska iz jednog načina ponašanja varijabli u drugi kao kontinuiran proces, u devetome poglavlju se obrađuju Markovljevi modeli promjene režima. Poglavlje započinje s VAR Markovljevim modelom i njegovim svojstvima i opsežnim primjerom. Potom je posebno potpoglavlje posvećeno simuliranim podacima i detaljnim interpretacijama za pojedini režim. Kako se ovdje pretpostavlja da procesi slijede Markovljev lanac, posebno potpoglavlje bavi se definicijom tog pojma i njegovih bitnih svojstava (poput homogenosti, ergodičnosti, ireducibilnosti itd.) koja moraju vrijediti kako bi analiza temeljem matrice prijelaznih vjerojatnosti bila pouzdana. U ovome poglavlju je vjerojatno najviše strana posvećeno metodi procjene ovakvih modela, s obzirom na njenu složenost, posebice u multivarijatnom slučaju. Stoga se na gotovo 10 stranica obrađuju ML metoda u slučaju modela promjene režima te dodatno algoritam maksimizacije očekivanja (*expectation-maximization algorithm*). Kraj poglavlja posvećen je testiranju hipoteza, broju režima (s naglaskom na problem nedostajućih (*nuisance*) parametara), prognoziranju te kombinaciji GARCH modela i metodologije promjene režima. Za praktičare može biti zanimljivo posljednje potpoglavlje u kojemu se komentiraju rezultati novijih empirijskih istraživanja na ovu temu. U dodatku ovoga poglavlja nalaze se formalniji zapisi i izvodi vezani uz modele promjene režima (poput ML metode procjene), a *online* se može naći na 24 stranice dodatka za ovo poglavlje, u kojemu se nalaze primjeri, testovi krive specifikacije (*miss-specification test*), klasifikacije režima, izvodi viših momenata distribucija koje slijede promjenu režima itd. Deseto poglavlje naziva se *Realizirana volatilnost i kovarijanca* te se ovdje definiraju ti pojmovi, s obzirom na sve veću dostupnost podataka unutar dana (*intraday data*). Stoga se ovdje razmatra osnovna mjera realizirane volatilnosti (kao suma kvadriranih prinosa), ali i druge mjere koje nisu pristrane poput ove osnovne mjere (npr. BNHLS procjenitelj,

Barndorff-Nielsen, Hansen, Lunde i Shephard). Prikazuju se mogućnosti prognoziranja temeljem realizirane volatilnosti pomoću ARMA modela, ali i heterogenog autoregresivnog modela (HAR) te se u primjerima uspoređuju rezultati različitih pristupa modeliranja. Realizirane kovarijance se obrađuju u drugom dijelu poglavlja te se ovdje nalazi dodatna vrijednost, s obzirom da se češće u literaturi obrađuje samo realizirana volatilnost.

Zaključno, može se reći da je pristup u knjizi takav da se može dobiti kvalitetna slika i temelji ekonometrije i financijskih vremenskih serija na kojima se lako dalje nadograđuje složenija literatura (pedagoški pristup). Kako su se autori usredotočili na financijske vremenske serije, prirodno je bilo uključiti ARMA i (M)GARCH modele te promjenu režima i realiziranu volatilnost. Doduše, postoje knjige koje se posvećuju samo jednome od navedenih pojmova, ali zato je navedeno da ova knjiga predstavlja kvalitetan uvod u navedenu tematiku. Izvori literature su dani na kraju svakoga poglavlja pa je lako pratiti i naći reference. S obzirom na sve navedeno, knjiga se preporuča studentima preddiplomskih i diplomskih studija, ali i praktičarima koji u financijama primjenjuju neku od obrađivanih tema. Knjiga je pisana razumljivim jezikom, s izvrsnim omjerom teorije i primjene. Knjiga daje dovoljno potrebne teorije koju je nužno znati kako bi se modeli i metode mogli primjenjivati u praksi. S druge strane, primjeri su mnogo opsežniji u odnosu na brojne postojeće udžbenike, stoga to može značajno pridonijeti svladavanju gradiva. Zato ova knjiga može biti zanimljiva svima koje zanima primjena kvantitativnih metoda u području financija, posebice analize prinosa i rizika, jer predstavlja solidan uvod u spomenuto područje.